

微型智能车控制系统中的神经网络模型研究*

朱秀炜 陆涛

南宁学院信息工程学院, 南宁, 530200

摘要 针对微缩车辆驾驶控制需求, 将深度学习、图像识别等技术用于微缩智能车的自适应巡航系统的设计, 提出了基于深度学习技术的卷积神经网络模型及其优化方法, 给出了模型设计与实现的“感知-决策-控制”方案。该模型可用于实现在微型道路上的自动驾驶、障碍识别和躲避。对微缩智能车进行的数据采集、系统训练和自动驾驶测试结果表明, 所提出模型和“感知-决策-控制”方案是可行和有效的, 可以运用到小型车辆以及智能机器人控制中。

关键字 深度学习, 卷积神经网络, 自动驾驶, 图像识别, 微缩智能小车

Research on Autonomous Driving Car Based on Deep Learning

Zhu Xiuwei Lu Tao

School of Information Engineering Nanning University
Nanning 530200, China;
961852656@qq.com

Abstract—According to the requirements of micro vehicle driving control, the technologies of deep learning and image recognition are applied to the design of adaptive cruise system of micro intelligent vehicle. The convolution neural network algorithm and its optimization method based on deep learning technology, vehicle control algorithm and image recognition algorithm are proposed to realize automatic driving, obstacle recognition and avoidance on micro road. The results of data acquisition, system training and automatic driving test of miniature intelligent vehicle show that the design of relevant algorithm are feasible and effective. The proposed "perception-decision-control" scheme can be applied to the control of small vehicles and intelligent robots.

Keyword—Deep learning, Convolution neural network, Autonomous driving, Image recognition, Miniature intelligent car

1 引言

目前, 人工智能发展的核心是深度学习技术的发展, 而深度学习技术的核心是神经网络算法和机器学习算法。研究者研究不同类型的神经网络结构来获得独特的场景应用, 例如要在众多图片中识别不同动物, 则需要设计一种图片识别与分类算法; 又如人们通过大数据来推断未来天气走向, 则需要设计一种预测算法。目前人们开发出的神经网络结构多达几十种, 每种神经网络结构根据特点有着不同的应用场景^[1]。

目前比较热门的深度学习应用场景之一在无人车辆和智能机器人上, 国内外许多企业都在从事这类系统的研发, 例如菜鸟快递的无人快递车, 百度无人车

等, 其核心技术在于自动驾驶、线路规划和人机交流, 其核心技术大量使用深度学习技术进行开发^[2]。除此之外, 搭载深度学习技术的智能机器人则可以解决许多需要人类才能完成的工作, 其中一个重要应用场景在于物品分类, 通过使用云计算、大数据技术或者独立的运算处理系统, 使得单个机器人不依赖大型机器分拣系统, 它可以拥有像人类一样的问题判断与解决问题的能力, 能够担任像人类一般的“全能选手”^[3]。

目前, 人工智能技术在智能驾驶、智能控制领域的应用还不是十分成熟。为此, 目前国外许多优秀大学和团队和研究^{[4][5][6]}也在大力开展智能驾驶和智能机器人领域的学习。

本文针对微型智能车自动驾驶控制需求, 研究和开发基于深度学习技术的微缩智能车自动控制驾驶系统。提出一种适用于微型车辆自动驾驶控制的卷积神经网络模型和深度学习训练的优化方法, 设计相应的

“感知-决策-控制”方案。该方案通过采用深度

* **基金资助:** 本文得到广西高校中青年骨干教师科研基础能力提升项目(2020KY64105)、南宁学院教授培育工程项目(2020JSGC03)资助。

通讯作者: 陆涛, 副教授, 9137339099@qq.com

学习技术、环境视觉感知技术和自动控制技术,使得微型智能车自动驾驶系统可以实现特定环境下的自适应巡航、障碍物识别和躲避。

2 微型智能车辆控制决策思路

在自动驾驶技术中,自动驾驶系统根据前方路况选择合适的前进路线是最基本、最核心的功能。人们驾驶车辆时,一般是根据道路的特定特征做出控制决策,例如道路的纹理、标线、特征细节、整体形状等。人类大脑无需通过视野中的所有内容来判断车道走向,而是聚焦于关键特征进行辨。因此即使在复杂环境、未知环境以及严重的视线干扰环境下,人类大脑依然能够做出较为准确的决策。如图1所示,不同的直线道路有许多相同特征能够用于线路走向预测。



图1 不同的直行路线的相似特征

人类驾驶汽车遇到直行道路时,大脑通过判断路线特征选择合适的油门速度,通过控制方向盘将转向居中。人类通过学习能够记住驾驶时直行路线的特征,从驾驶室视角观察,直行道路在人眼中处于如图中的梯形形状。当车向与道路偏离时时,梯形特征会变成倾斜梯形,此时驾驶员会做出轻度的角度调整使其回归正常航线。当道路遇到急弯道时,道路梯形特征转变成更大幅度的倾斜梯形,同时在远处向一侧汇聚,此时驾驶员需要做出与实际弯道相符的转向操作。

显然,在人的眼中,道路两侧的环境与路面形成了反差明显的纹理特征,同时在现实道路中,浅色的路标线也为人眼提供了明显的识别特征。因此,人类即使在光线很差的环境下依然能够作出正确决策。

因此构建智能车辆自动驾驶的基本控制系统不仅需要控制合适的车速、转向角度,也需要能够在复杂路况下感知路线走向,识别关键特征。本文提出的微型智能车控制决策方案的技术思路是:使用深度学习(Deep Learning)算法模拟人类开车时对车辆的驾驶决策,再辅以控制算法实现车辆的驱动控制。深度学

习系统通过摄像头感知车辆前方道路特征进行决策和车辆控制,因此深度学习模型的选择尤为重要。本文的重点是深度学习模型的研究。

3 深度学习神经网络类型对比与选择

对于目前的人工神经网络而言,单一神经网络模型通常由“输入层-隐藏层-输出层”构成,不同类型的神经网络最核心的区别在于隐藏层的设计。普通神经网络模型的隐藏层中,层与层之间的每个神经元都会与上、下层的所有神经元进行连接,一般称之为神经元的全连接。由于全连接的存在,单一层的神经元具有相同的权重,神经网络在学习过程中,所有输入维度的权重是完全相同的,反映到图像识别中就是传统神经网络无法对局部进行判断,所有输入内容都会影响最终输出结果。车辆的自动驾驶需要能够识别输入图像的关键局部特征来实现线路预测。通过简单分析可知,传统神经网络模型无法运用在图像的部分特征识别,因此不适合本系统的自动驾驶决策设计。

车辆行驶时前方道路视角如图2所示,对于自动驾驶来说,神经网络需要捕捉打小四方框部分的关键信息,该部分关键信息有明显边界纹理以及弯道的曲线特征,可作为神经网络决策判断的重要依据。图中黑色方框中的图像内容与预测无关,通常用于输入的数据为摄像头采集的完整图像,这部分无关图像特征便会对预测结果造成干。因此,智能车自动驾驶选用的深度学习模型必须能够正确激活有用特征并排除干扰特征,而卷积神经网络模型正好拥有识别输入内容关键特征的能力。




图2 道路弯道细节而特征图

卷积神经网络(Convolutional Neural Networks, CNN)是在传统的全连接神经网络中加入了卷积层(convolutional layer)的概念,卷积神经网络是一类包含卷积计算且具有深度结构的前馈神经网络^[7]。卷积神经网络具有表征学习能力,采用梯度下降算法进

行学习，卷积层与卷积层的连接区域在视觉识别中类似于生物神经网络中的“感受野”，卷积神经网络通过“感受野”能够响应输入数据的不同特征。这种对输入内容具有权重概念的神经网络可以实现诸如图像识别、语音识别、自动驾驶等功能。

如图 4 所示，卷积神经网络与传统神经网络一样由输入层、隐藏层、输出层构成。与传统神经网络不同的是其隐藏层由选择性连接的网络层构成，其中包括卷积层、池化层、平面层、全连接层等。在图像识别中，卷积层可以提取不同特征，再通过池化层降低特征数量和分辨率，使用多个不同参数的卷积层的选择性连接来获得更加抽象的特征，再经过其他处理，便可获得较为全面的输入特征。对于图像识别来说，卷积层的作用就是通过复杂的学习来提取目标的特征，这些特征传入全连接层，通过特征以及目标值的映射，便实现了图像分类。




图 3 卷积神经网络模型结构

4 自动驾驶控制系统设计与相关技术

4.1 系统架构

本文的微型智能车自动控制系统的的设计采用深度学习决策算法和端对端控制（End-To-End Control）的自动驾驶架构，构建一个端对端的自动驾驶系统。




图 4 智能车端对端学习系统流程图

该系统学习驯良流程图如图 4 所示，系统的训练样本使用车载摄像头采集的图像集和人工输入的控制信号对小车的深度学习模块进行训练，通过训练成型的神经网络模型实现小车在小型跑道的自动驾驶与避

障。

在训练阶段，使用人工控制车辆驾驶的方式进行训练数据的采集，包括车辆前方路况的视频流和人工控制的转向和油门信号，并将视频流以图片集加标签的形式存储，转向信号和油门信号以浮点数形式存储并与图片标签进行匹配。获取的图片集、控制信号数据作为神经网络模型的输入样本和标签，通过分批次的迭代训练，通过正向-反向传播的方式训练模型，在完成设定训练次数或获得最优模型后输出训练成型的神经网络模型文件。

在控制阶段，将摄像头的视频流数据输入训练成型的神经网络模型，并获取实时预测值将其作为小车控制信号，开启小车驾驶线程，依靠循环进程中高频率的数据流和的预测输出，通过控制模块控制车辆前进以及转向。

4.2 卷积神经网络模型

本文智能车控制系统采用的是卷积神经网络。神经网络模型设计如图 5 所示，输入层为长度 $H=160$ 像度，宽度 $W=120$ 像素的 RGB 通道图像，通过预处理，单幅图像转换成 $160 \times 120 \times 3$ 格式作为输入层。隐藏层的第一、二、三、四、五层为卷积层，第一、二、三、四、五层卷积层深度分别为 24、32、64、64、64，卷积核大小分别为 5×5 、 5×5 、 5×5 、 3×3 、 3×3 ，卷积层通过平面化处理输出到两个全连接层，全连接层再接输出层。神经网络的输出层使用两种不同方案：第一种方案使用两个单独输出层分别输出转向和油门，输出方式为线性输出；第二种方案使用控制分类输出，将油门进行 10 个分类，转向进行 15 个分类，使用一个输出层输出分类预测。

模型采用梯度下降算法，使用前向传递和反向传递进行训练。卷积神经网络的输入特征需要进行标准化处理，首先对输入的学训练数据进行归一化处理，将 $[0,255]$ 区间内的原始像素归一至 $[0,1]$ 区间。将输入特征标准化可以提升卷积神经网络的学习效率[9]。

(1) 核心卷积层

卷积层（convolutional layer）是构建卷积神经网络的核心^[9]。在本文模型中，卷积层的作用是逐层对图像特征进行提取，并将不同的特征通过选择性连接的“感受野”进行逐层传递来构建更抽象的特征。卷积层堆由多个单独卷积层进行选择连接而成，卷积层由一些可进行学习的卷积核（Convolution）构成，卷积核为具有单位大小的正方形，本文的卷积核采用

的是大小为 5×5 和 3×3 小卷积核。使用小卷积核深层次的结构使得非线性更强，可以输出更多更精确的特征值，同时减小参数数目^[10]。

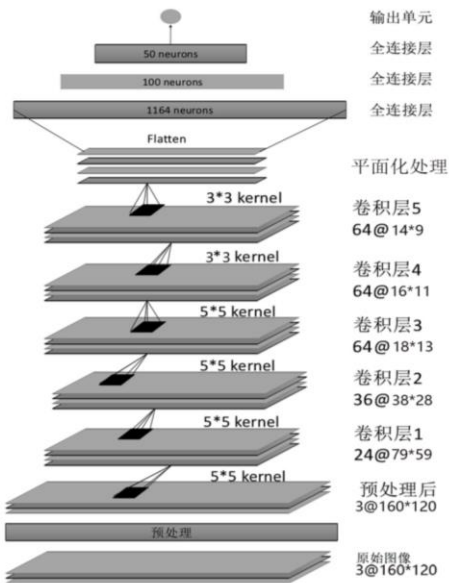


图 5 CNN 网络结构图

卷积神经网络的学习通过前向传播和反向传播进行，神经网络在前向传播时，卷积核会在输入的图像数据的高度和宽度上进行平移，计算与之划过的数据块之间的内积。如图 6 所示。




图 6 卷积计算示意图

在同一卷积层中，不同的卷积核具有不同的权重，每个权重负责一类基本特征。在神经网络未经训练时，卷积核权重处于默认值，卷积计算得到的值经过激活函数进入到下一层，作为下一层神经元的输入值。卷积核划过整个输入数据体后得到一张特征图（Feature Map），每个神经元输出的特征图会根据自身权重显示出明暗相间的灰度图，高亮的部分表示该部分图像与自身权重高度适应。卷积神经网络在通过迭代多次的

正向传播以及反向传播后，反向传播会根据实际预测效果更新权重，此时神经元的权重不再是默认参数，而是与神经网络目标值密切相关的权重，通过训练，当卷积核学习到有用的特征时，特征在特征图中就会处于高亮状态，此时输出的特征图叫做激活图（activation Map）^[11]，激活图的有用特征会处于高亮状态，而其他特征处于灰暗状态。

卷积神经网络的每层卷积层包含多个卷积核，也称之为卷积层的深度，本系统神经网络模型的第一层卷积层有 24 个卷积核，计算时会得到 24 个特征图，将这些特征图进行叠加便形成了该层的输出，通过池化层（Pool Map）可将许多相同的特征过滤，降低了输出特征数量以及分辨率，可以有效提升训练效率，本文的卷积神经网络由于使用较小的输入数据体，无须使用池化层即可获得较好的训练效果。

卷积层设计的关键参数有输入数据尺寸 W ，卷积核数量 C ，步长（stride）、填充（padding）、深度和激活函数等。数据输入到卷积层进行学习时，卷积核滤波器会在数据体沿着宽度和高度滑动进行卷积运算，每次卷积核滤波器会滑动单位像素^[10]，像素的个数即为步长，通常步长值 S 为 1 或者 2，本设计中第一、二、三层卷积层步长设为 2，第四、五层卷积层步长设为 1。当步长 $S > 1$ 时，输出的数据体会变小，通常通过添加填充 P 来使得输出数据体在宽度和高度上相对大小保持一致^[13]。卷积神经网络的输出数据 W' 计算公式如下：

$$W' = (W + 2P) / S - 2 \quad (1)$$

在本设计中输入数据体高度 $H=120$ ，宽度 $W=160$ ，通道数为 3。第一层卷积层的卷积核数量为 24，步长 $S=2$ ， $P=1/2$ ，输出宽度 $W' = (120+2)/2-2=59$ ，输出高度 $H' = (160+2)/2-2=79$ 。第二层等接下来四层的卷积层大小以此类推，卷积网络层结构如图 5 所示。

(2) 添加激活函数

在深度学习神经网络中，添加激活函数的作用是给神经网络添加一些非线性因素，使得网络可以更好地处理较为复杂的问题^[10]。在本文系统设计中添加的激活函数是为了能够突出输入图像特征的梯度值，表现出特征的稀疏性，以便更好地解决特征识别的问题，使用激活函数有助于缩短训练时间。

对于普通的线性分类，只能实现简单的线性分类，无法实现如图 7 所示的非线性分类。为此，需要引入复杂函数来进行区分。

近几年,人们常用 ReLU 激活函数、Sigmoid 函数进行分类。其中, Sigmoid 函数称作二分类函数,曾被广泛地应用,但由于其自身的一些缺陷,现在已经很少被使用。Sigmoid 函数定义如下^[10]:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$




图 7 激活函数 sigmoid 分类效果图

本文系统通过使用近几年流行的 ReLU 激活函数进行分类。我们在 ReLU 激活函数中引入稀疏性,函数表达式如下:


$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2)$$

Sigmoid 函数和 ReLU 函数图像对比如图 8 所示。从图 8 中可以看出, Sigmoid 函数在 x 接近 0 时具有最高梯度,当 x 远离 0 时其导数 $f'(x)$ 的值趋于 0,出现了软饱和现象(即无法有效呈现不同输入特征的梯度值),在卷积神经网络的梯度回传中将导致出现梯度“被杀死”现象,无法适用于卷积神经网络模型中^[11]。而 ReLU 函数图像在 $x > 0$ 时呈现出梯度上升曲线,具有非饱和性,可以有效避免梯度消失的现象。


在本系统设计的神经网络模型中,所有隐藏层都采用 ReLU 激活函数^[12]。目的是利用 ReLU 激活函数具有的加快神经网络收敛的作用,有效地将卷积层捕捉的特征值进行稀疏分类并输入下一网络层,确保神经网络模型梯度传递的正确性。同时通过加快模型收敛速度,提升训练速度、质量和效果。

在本系统决策设计中智能小车的分类输出模型需要将值输出以概率的形式展现出来,因此需要使用 Softmax 函数对输出进行归一化处理。Softmax 函数是 Sigmoid 在多分类上的推广^[13],图 9 展现了 Softmax 函数的计算方法。

Softmax 函数首先将模型的预测结果输出到指数函数上 $[y=e]^x$ 上,保证了结果的非负性,指数函数 $[y=e]^x$ 的图像如图 10 所示。



(a) Sigmoid 函数图像



(b) ReLU 函数图像

图 8 Sigmoid 函数和 ReLU 函数图像对比

其次将转化的结果归一化处理,确保各个输出结果之和等于 1。具体做法是:将转化后的结果除以所有输出结果之和,可以理解为转化后的结果占总结果的百分比。通过这种方式可以获得近似概率,将近似概率转换成分类输出。

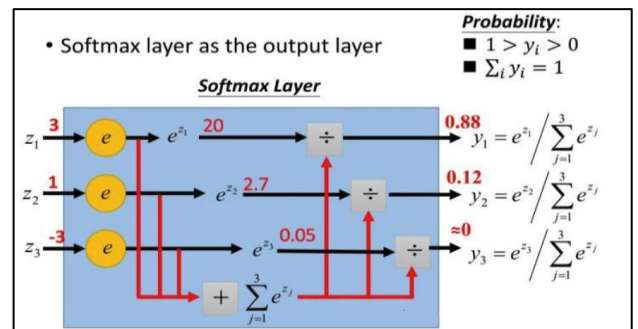


图 9 Softmax 函数计算输出层结果

在本系统设计的线性输出模型中,通过模型输出具体值进行控制决策,以获得线性输出结果。而在分类输出模型中,输出层使用 Softmax 激活函数将值输出转换成区间概率,可以将输出结果较为简单地转换成分类结果。小车使用线性输出可以获得细腻的车辆转向以及油门控制。与线性输出模型相比,分类输出模型虽然输出较为粗糙的控制信号,但通过增减分类区间,可以灵活地调整神经网络的复杂度、所需训练

时间和数据量。




图 10 指数函数 $y = e^x$ 的图像

(3) 添加随机失活

添加随机失活 (Dropout) 是为了添加随机失活的神经元到网络层中, 通过添加随机失活可以定义损失率, 通过损失率, 损失函数会将该层中的神经元依照损失比例随机失活, 如图 11 所示。

通过在网络层中添加损失函数的办法可以选择性地让部分神经元失活, 失活的神经元将不参与到任何训练和预测中, 减少特征参数, 由于失活的神经元是随机的, 每次迭代训练时神经网络都可以获得不同的特征参数, 可以有效降低过拟合的发生, 保证模型对预测的准确性^[14]。




图 11 普通神经元与随机失活神经元结构对比图

通过在网络层中添加损失函数的办法可以选择性地让部分神经元失活, 失活的神经元将不参与到任何训练和预测中, 减少特征参数, 由于失活的神经元是随机的, 每次迭代训练时神经网络都可以获得不同的特征参数, 可以有效降低过拟合的发生, 保证模型对预测的准确性^[15]。

(4) 目标检测

目标检测采用了基于形状检测的方法, 并使用了基于 Haar 特征的级联分类器进行目标检测^[18]。由于每个对象都需要自己的分类器, 并且在训练和检测中遵循相同的过程, 因此本文系统设计仅关注停车标志和交通信号灯检测。

OpenCV 开发工具提供了培训程序和检测器。使用手机获取阳性样本 (包含目标对象), 并将其裁剪为仅可见所需对象, 然后在测试环境中随机收集阴性样本 (无目标环境图)。小型交通灯阳性样本包含相等数量的红色交通信号灯和绿色交通信号灯。停车标志和交通信号灯训练均使用相同的阴性样本数据集。

为了识别交通信号灯的不同状态 (红色, 绿色), 除了检测之外还需要进行一些图像处理。图 12 给出了交通信号灯识别过程。




图 12 分类器的交通灯识别过程

经过训练的分类器用于检测交通信号灯, 首先, 检测程序将检测器感兴趣的区域 (ROI) 用矩形括起来。其次, 在 ROI 内部应用高斯模糊以减少噪声。第三, 找到检测区域中的最亮点。最后, 根据 ROI 中最亮点的位置确定交通灯处于红色或绿色状态。

(5) 卷积神经网络的训练

卷积神经网络的训练分为两个阶段: 第一阶段为正向传播, 数据由低层次向高层次传播, 输入的图像数据经过多层卷积层的处理, 提取出特征向量, 再通过平面层将数据平面化, 最后输出到全连接层, 得出分类识别结果。如果输出结果与期望结果相符则, 则固定该次训练的权值和阈值, 将结果进行储存。另一阶段为反向传播, 当正向传播的结果与预期不符时开始反向传播阶段, 将误差从高层网络向低层网络回传进行训练, 依次求得全连接层、采样层、卷积层的误差, 各层的误差相当于总误差对于层级应该承担的部分。当回传训练误差小于或者等于我们的期望时停止训练并更新训练各层的权重。训练流程如图 12 所示。

参考文献

- [1] 陈先昌. 基于卷积神经网络的深度学习算法与应用研究[D]. 杭州: 浙江工商大学, 2014.
- [2] 鲁嘉淇. 浅析基于视觉识别的自动化技术在快递企业中的应用——以顺丰自动分拣机器人为例[J]. 中国战略新兴产业, 2017(12): 132-133.
- [3] 徐国华, 谭民. 移动机器人的发展现状及其趋势[J]. 机器人技术与应用, 2001(03): 7-14.
- [4] 张新钰, 高洪波, 赵建辉, 周沫. 基于深度学习的自动驾驶技术综述[J]. 清华大学学报(自然科学版), 2018, 58(04): 438-444.
- [5] 张文. 一键呼叫免费试乘 无人驾驶出租车真的来了! [J]. 人民交通, 2020(05): 36-37.
- [6] 陈慧, 徐建波. 智能汽车技术发展趋势[J]. 中国集成电路, 2014, 23(11): 64-70.
- [7] 潘逸涵. 基于深度学习的Tor 流量识别方法[J]. 通信技术, 2019, (12): 2982-2986.
- [8] Srivastava N, Hinton G E, Krizhevsky A, et al. Dropout: a simple way to preventneural networks from overfitting. [J]. Journal of Machine Learning Research, 2014, 15(1) : 1929 - 1958.
- [9] 张露. 基于卷积神经网络的图像识别分析[J]. 数字化用户, 2018, (8): 13-14
- [10] 白辰甲. 基于计算机视觉和深度学习的自动驾驶方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
- [11] 梁治钢. 深度学习在抗菌药物数据分析中的应用[J]. 中国新通信, 2019, (14): 147-148.
- [12] 蔡博伟. 基于膜馈神经网络的焓差试验台故障预测[J]. 制冷技术, 2018, (6): 47-53
- [13] 焦亮. 基于机器视觉的随机纹理瓷砖的分选系统[J]. 计算机系统应用, 2016, (3): 93-100.
- [14] 李大中. 大数据驱动下的风电机组工作状态决策树判别方法[J]. 电力科学与工程, 2020, (2): 22-27.
- [15] 刘琼. 基于视觉选择性注意与 IHOG-LBP 特征组合的行人目标快速检测[J]. 计算机应用研究, 2016, (1): 281-285.

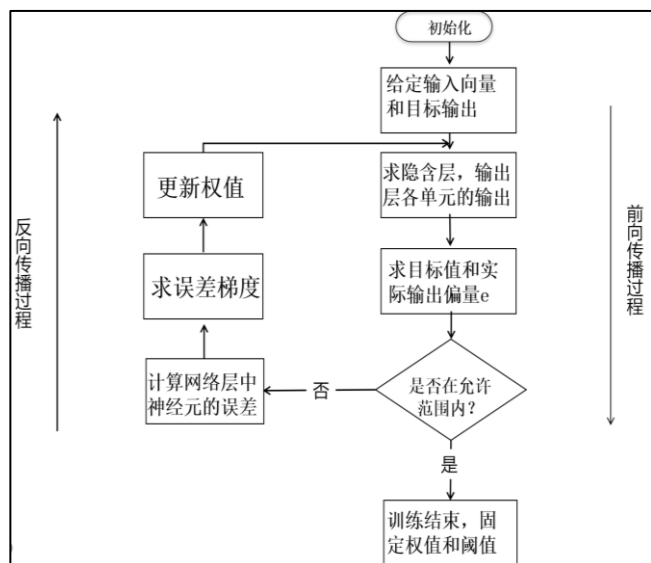


图 13 训练流程图

5 结束语

本文将深度学习技术与车辆控制技术相结合, 提出了适用于微型智能车自动控制系统的卷积神经网络模型、神经网络的优化方法、机器学习训练的优化方法、障碍识别、红绿灯交通灯状态识别的算法等, 探究了不同神经网络算法的效果差异。本文提出的模型和“感知-决策-控制”方案用于微型智能车自动控制决策系统的设计与实现, 完成了基本自动驾驶技术的实验、分析和验证, 分析了不同神经网络结构、不同训练方法、不同驾驶策略的影响。实验数据结果表明, 模型和相关算法的设计是可行和有效的。